

(19) **RU** (11) **2 166 207** (13) **C2** (51) Int. Cl. 7 **G 06 F 17/20, 17/21, 17/22,** 17/27, 17/28

RUSSIAN AGENCY FOR PATENTS AND TRADEMARKS

(12) ABSTRACT OF INVENTION

- (21), (22) Application: 99106483/09, 08.04.1999
- (24) Effective date for property rights: 08.04.1999
- (46) Date of publication: 27.04.2001
- (98) Mail address: 115573, Moskva, Orekhovyj bul'var, d.39, korp.1, kv.145, Linniku L.N.
- (71) Applicant: Zakrytoe aktsionernoe obshchestvo "Abi Programmnoe obespechenie"
- (72) Inventor: Anisimovich K.V., Tereshchenko V.V., Jan D.E.
- (73) Proprietor: Zakrytoe aktsionernoe obshchestvo "Abi Programmnoe obespechenie"

(54) METHOD FOR USING AUXILIARY DATA ARRAYS IN CONVERSION AND/OR VERIFICATION OF CHARACTER-EXPRESSED COMPUTER CODES AND RESPECTIVE SUBPICTURES

(57) Abstract:

တ

N

FIELD: electronics. SUBSTANCE: method involves retrieval of significant units of that recognized subpictures to be incorporate n component pixels, where n is chosen within 1≤n≤10³ range. Sets of subpictures to be verified that have n₁ pixels are selected, where n₁ is chosen within $1 \le (n_1+n)/n \le 2$ range. Significant units that differ from selected sets of subpictures are retrieved in auxiliary data array with error ε chosen within $0 \le \varepsilon \le (\alpha n_1 - 1)/n_1$ range, where α is experimental factor within 0,6 $\leq \alpha \leq$ 1,2 range selected as function of rate of occurrence of any i-th significant unit in permissible set of significant units which is defined as repetitive quantity n2 of

significant units total quantity n₃ of significant units in their permissible set. Pixels that do not coincide with characters equivalent to them in location in significant units found in the course of retrieval are detected recognized significant units equivalent to them in location and replaced by characters of respective location retrieved from significant units found. Additional array of dynamic raster standards of computer codes of recognizable formed as part significant units and auxiliary data array is converted, bearing in mind preceding operations, until total error ϵ_3 of method chosen relative to intermediate error ϵ_1 is reduced within $1 \le (\epsilon_1 + \epsilon_3)/\epsilon_1 \le 2$. range. EFFECT: reduced conversion and/or verification error.



RU⁽¹¹⁾ 2 166 207 ⁽¹³⁾ C2

(51) MПK⁷ G 06 F 17/20, 17/21, 17/22, 17/27, 17/28

РОССИЙСКОЕ АГЕНТСТВО ПО ПАТЕНТАМ И ТОВАРНЫМ ЗНАКАМ

(12) ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ПАТЕНТУ РОССИЙСКОЙ ФЕДЕРАЦИИ

- (21), (22) Заявка: 99106483/09, 08.04.1999
- (24) Дата начала действия патента: 08.04.1999
- (46) Дата публикации: 27.04.2001
- (56) Ссылки: WO 98/24036 A1, 04.06.1998. RU 2112273 C1, 27.05.1998. WO 96/34348 A1, 31.10.1996, WO 98/00794 A1, 08.01.1998, RU 2096825 C1, 20.11.1997. US 5477451 A1, 19.12.1995.
- (98) Адрес для переписки: 115573, Москва, Ореховый бульвар, д.39. корп.1, кв.145, Линнику Л.Н.

- (71) Заявитель: Закрытое акционерное общество "Аби Программное обеспечение"
- (72) Изобретатель: Анисимович К.В., Терещенко В.В., Ян Д.Е.
- (73) Патентообладатель: Закрытое акционерное общество "Аби Программное обеспечение"

(54) СПОСОБ ИСПОЛЬЗОВАНИЯ ВСПОМОГАТЕЛЬНЫХ МАССИВОВ ДАННЫХ В ПРОЦЕССЕ ПРЕОБРАЗОВАНИЯ И/ИЛИ ВЕРИФИКАЦИИ КОМПЬЮТЕРНЫХ КОДОВ, ВЫПОЛНЕННЫХ В ВИДЕ СИМВОЛОВ, И СООТВЕТСТВУЮЩИХ ИМ ФРАГМЕНТОВ ИЗОБРАЖЕНИЯ

တ

C

Изобретение относится к области электроники и предназначено, например, для использования вспомогательных массивов данных в процессе преобразования и/или компьютерных верификации выполненных виде символов. R соответствующих фрагментов им изображения. Техническим результатом является снижение погрешности преобразования и/или верификации. Способ заключается в том, что производят выработку распознаваемых смысловых единиц фрагментов изображения, содержащих п составляющих их элементов, где n выбирают в пределах 1≤п≤10³. В отобранных выборках верификации выделяют подлежащие совокупности их фрагментов изображения, содержащие n₁ элементов, где n₁ выбирают в пределах 1≤(n₁+n)/n≤2. Осуществляют поиск вспомогательном массиве данных смысловых единиц, отличающихся от выделенных совокупностей фрагментов изображения, с погрешностью є, выбираемой в пределах $0 \le \le (\alpha n_1 - 1)/n_1$, где α экспериментальный коэффициент в пределах

0,6≤α≤1,2, выбираемый в зависимости от частоты f_i появления любой смысловой i-й единицы в допустимом множестве смысловых единиц, которую определяют количество n₂ повторений конкретной смысловой единицы, соотнесенное с общим количеством пз смысловых единиц в допустимом множестве смысловых единиц. Выявляют в распознанных смысловых единицах элементы, которые не совпадают с эквивалентными им по месту расположения символами в смысловых единицах, найденных в процессе поиска, и производят их замену соответствующими им по месту расположения символами из найденных смысловых единиц. дополнительный Формируют массив динамических растровых эталонов компьютерных кодов элементов в составе распознаваемых смысловых единиц и с предшествующих операций преобразуют вспомогательный массив данных уменьшения итоговой до погрешности ϵ_3 способа, которую выбирают отношению промежуточной К

погрешности ε_1 в пределах $1 \le (\varepsilon_1 + \varepsilon_3)/\varepsilon_1 \le 2$.

Изобретение относится к области электроники и может быть применено, например, для использования вспомогательных массивов данных в процессе преобразования и/или верификации компьютерных кодов, выполненных в виде символов, и соответствующих им фрагментов изображения.

использования способ Известен процессе вспомогательных данных в преобразования компьютерных кодов и соответствующих фрагментов им изображения, включающий производимое человеком и/или заменяющим. устройством, и/или компьютерной программой использование вспомогательных данных, для распознавания привлекаемых соответствующих им оригиналов [Patent USA N 5153927: Character reading system and method., MΠK Oct. 6, 1992.].

Известен также способ использования вспомогательных массивов данных в процессе преобразования и/или верификации компьютерных кодов и соответствующих им оригиналов, заключающийся осуществляемом компьютерной программой использовании вспомогательных массивов данных, привлекаемых для распознавания соответствующих им оригиналов [Руководство пользователя Fine Reader 4.0 © ABBYY Software House, М. , 1998. Казанский производственный комбинат программных средств. Заказ Ф-377].

Недостатком известных способов являются относительно низкие их функциональные и технические характеристики, в том числе высокие значения достигаемых погрешностей преобразования.

Решаемой изобретением задачей является совершенствование способов использования вспомогательных массивов данных в процессе преобразования и/или верификации компьютерных кодов, выполненных в виде символов, и соответствующих им фрагментов изображения с достижением технического результата в виде снижения погрешности преобразования и/или верификации.

Для удобства и однозначного понимания целесообразно привести расшифровки и определения используемых далее обозначений, символов и/или терминов.

Оригинал - преобразуемая информация, материализованная преимущественно в виде совокупности компьютерных кодов, соответствующих исходному объекту, например распознаваемому фрагменту изображения.

တ

Компьютерный код (например, символ) - компьютерное представление некоторого фрагмента информации (в частности, символьной).

Процесс распознавания - процесс обработки системой распознавания введенного в компьютер графического изображения некоторого символа, в результате чего система распознавания приписывает изображению компьютерный код этого символа.

Процесс верификации - производимое человеком и/или заменяющим его устройством, и/или компьютерной программой сличение (определение адекватности) компьютерных кодов (символов) с графическим изображением, введенным в компьютер.

Допустимое множество смысловых единиц включает в себя всю совокупность вероятных для распознавания наборов смысловых единиц.

Смысловая единица - это совокупность компьютерных кодов, соответствующих ориентированному на какое-либо практическое использование образу, например букве, слову, символу, графическому элементу, логической операции, их совокупности и др.

Вспомогательный массив данных - это произвольным образом сформированная совокупность электронных кодов смысловых единиц, охватываемых, в частности, допустимым множеством смысловых единиц.

10

Погрешность соответствия ϵ между исходными смысловыми единицами и соответствующими им смысловыми единицами объема n_1 в дополнительном массиве данных, определяется как допустимое число $\triangle n_1$ несовпадающих в них элементов, соотнесенное с n_1 : $\epsilon = \triangle n_1/n_1$.

Частота f_i появления любой смысловой i-й единицы в допустимом множестве смысловых единиц определяется как количество n 2 повторений конкретной смысловой единицы, соотнесенное с общим количеством из смысловых единиц в допустимом

множестве смысловых единиц: $f_1 = n_2^{1}/n_3$.

Погрешность ϵ_1 вспомогательного массива данных по отношению к допустимому множеству смысловых единиц определяется, как вероятность не нахождения в массиве данных элемента n_i , соотнесенного с общим количеством смысловых единиц n_4 во вспомогательном массиве данных.

Погрешность ϵ_2 преобразования определяется как количество n ϵ_3 ошибочно преобразованных элементов, соотнесенные с общим количеством ϵ_3 элементов в преобразуемом наборе смысловых элементов из их допустимого множества: $\epsilon_2 = n_5/n_6$.

Погрешность ϵ_3 определяется как итоговая погрешность преобразования.

Дополнительный массив динамических растровых эталонов - это совокупность элементов смысловых единиц, формируемая в процессе преобразования для уменьшения погрешностей ε_1 , ε_2 .

В качестве кратких сведений, раскрывающих сущность изобретения следует что достигаемый технический С обеспечивают результат помощью предложенного способа использования вспомогательных массивов данных в процессе верификации преобразования и/или компьютерных кодов, выполненных в виде символов, и соответствующих им фрагментов изображения, заключающегося в том, что производят выборку смысловых единиц распознаваемых фрагментов изображения, содержащих п1 составляющих их элементов, где n_1 - выбирают в пределах 1 ≤ n ≤ 10^3 . В отобранных выборках выделяют подлежащие верификации совокупности их фрагментов изображения, содержащие n 1 элементов, где n_1 выбирают в пределах 1 ≤ $(n_1+n)/n \le 2$. Осуществляют поиск во вспомогательном массиве данных смысловых единиц, отличающихся от выделенных совокупностей изображения, фрагментов

-3-

погрешностью є выбираемой в пределах 0 ≤ ε ≤ $(\alpha n_1 - 1)/n_1$. Здесь экспериментальный коэффициент в пределах 0,6 $\leq \alpha \leq$ 1,2, выбираемый в зависимости от частоты f, появления любой смысловой i-й единицы в допустимом множестве смысловых которую определяют повторений конкретной количество n_2 смысловой единицы, соотнесенное с общим количеством n₃ смысловых единиц допустимом множестве смысловых единиц.

Выявляют в распознанных смысловых единицах элементы, которые не совпадают с эквивалентными им по месту расположения символами в смысловых единицах, найденных в процессе поиска, и производят их замену соответствующими им по месту расположения символами из найденных смысловых единиц. Формируют дополнительный массив динамических растровых эталонов компьютерных кодов элементов в составе распознаваемых СМЫСЛОВЫХ единиц количеством п7, величину которого выбирают в пределах $1 \le (n_2 + n_5 + n_6 + \beta n_7 +$ n $_3)/n_3 \, \leq \, 6,3.$ Здесь $\, \beta \,$ - - экспериментальный коэффициент в пределах $0.4 \le \beta \le 1.3$, выбираемый в зависимости от задаваемых погрешности є вспомогательного массива данных по отношению к допустимому множеству смысловых единиц, определяемой как вероятность не нахождения в массиве данных элемента п_і, в общем количестве смысловых единиц n₄ во вспомогательном массиве данных, погрешности €2 преобразования, определяемой как количество n 5 ошибочно преобразованных элементов, соотнесенное с общим количеством n_6 элементов преобразуемом наборе смысловых элементов из их допустимого множества. Затем с учетом предшествующих операций преобразуют массив вспомогательный данных уменьшения итоговой

погрешности ϵ_3 способа, которую выбирают по отношению к погрешности ϵ_1 в пределах $1 \le (\epsilon_1 + \epsilon_3)/\epsilon_1 \le 2.$

N

ത

ത

2

При изложении сведений, подтверждающих возможность осуществления изобретения целесообразно более подробно описать предложенный способ использования вспомогательных массивов данных в процессе верификации преобразования и/или компьютерных кодов и соответствующих им изображения. Детально целесообразно остановиться только на существенных особенностях осуществления предложенного операций способа. заключающегося в том, что производят выборку смысловых единиц распознаваемых фрагментов изображения, содержащих n составляющих их элементов, где n - выбирают в пределах 1 ≤ n ≤ 10³. Смысловыми единицами могут быть в произвольном случае буквы, математические и другие символы, отдельные слова, предложение, графические элементы, а также их любые сочетания. В отобранных выборках выделяют подлежащие верификации совокупности их фрагментов изображения, содержащие n ₁ элементов, где n_1 выбирают в пределах $1 \le (n_1+n)/n \le 2$. Осуществляют поиск во вспомогательном

смысловых массиве данных отличающихся от выделенных совокупностей фрагментов изображения, с погрешностью є, выбираемой в пределах $0 \le \varepsilon \le (\alpha n_1 - 1)/n_1$. Здесь α - экспериментальный коэффициент в пределах $0.6 \le \alpha \le 1.2$, выбираемый в зависимости от частоты f_i появления любой смысловой і-й единицы в допустимом множестве смысловых единиц, которую определяют как количество n 2 повторений конкретной смысловой единицы, соотнесенное с общим количеством п₃ смысловых единиц в допустимом множестве смысловых единиц. Фрагментами могут быть как смысловые единицы в целом, так и их части, ориентированные, например, на автономное применение. Погрешность преобразования в основном связана с качеством исходных графических изображений, которое определяется, в частности, тем, предъявляют для распознавания, например, изготовленное на ксерокопировальном изображение, факсограмму, аппарате машинописный или рукописный текст.

Выявляют в распознанных смысловых единицах элементы, которые не совпадают с эквивалентными им по месту расположения символами в смысловых единицах, найденных в процессе поиска, и производят их замену соответствующими им по месту расположения символами из найденных смысловых единиц. дополнительный Формируют динамических растровых эталонов компьютерных кодов элементов в составе распознаваемых СМЫСЛОВЫХ единиц количеством п₇, величину которого выбирают в пределах $1 \le (n_2 + n_5 + n_6 + \beta n_7 + \beta$ $n_3)/n_3 \le 6,3$. Здесь β - экспериментальный коэффициент в пределах $0.4 \le \beta \le 1.3$, выбираемый в зависимости от задаваемых погрешности ϵ_1 вспомогательного массива данных по отношению к допустимому множеству смысловых единиц, определяемой как вероятность не нахождения в массиве данных элемента пі, в общем количестве смысловых единиц n_4 во вспомогательном

погрешности є2 преобразования, определяемой как количество п $_5$ ошибочно преобразованных элементов, соотнесенное с общим количеством n_6 элементов в преобразуемом наборе смысловых элементов из их допустимого множества.

данных.

массиве

динамических Процесс построения растровых эталонов целесообразно определить как производимое человеком и/или заменяющим его устройством, и/или программой компьютерной построение дополнительного массива данных. используемых для ускорения процесса распознавания. Динамический растровый эталон - это дополнительный массив данных, создаваемый и используемый для ускорения процесса распознавания. Понятие "динамический" отражает изменяемый характер создаваемых эталонов, то есть означает, что в процессе использования предложенного способа постоянно изменяют совокупность построенных пополнением ee новыми эталонами. видоизменением существующих нөнужных, исключением а понятие

-4

"растровый" характеризует их особенности выполнения в виде совокупности элементов, образующих, например, периодическую структуру. Создать эталон - значит для каждого встречающегося в тексте символа записать в память растровой подсистемы пару: точечное изображение символа и его название (т.е. какую буквы это изображение представляет).

Затем с учетом предшествующих операций преобразуют вспомогательный массив данных итоговой до уменьшения погрешности ϵ_3 способа, которую выбирают по отношению к погрешности ϵ_1 в пределах $\leq (\epsilon_1 + \epsilon_3)/\epsilon_1 \leq 2$. На практике возможно использование и отдельных совокупностей операций завершенных предложенного способа. Если в результате выделения в соответствии с приведенными аналитическими соотношениями необходимых величин получают дробные, отрицательные значения и какие-либо другие значения, некорректные исходя из условий возможности их дальнейшего использования, то их рассмотрения исключают из автоматически удаляют.

примера качестве практического выполнения заявленного способа использования вспомогательных массивов данных в процессе преобразования и/или верификации компьютерных кодов соответствующих им фрагментов изображения, целесообразно привести следующий, реализованный в последних версиях системы оптического распознавания текстов FineReader. В процессе реализации способа производят выборку смысловых распознаваемых единиц оригиналов. содержащих п составляющих их элементов, где n - выбирают в пределах 1 ≤ n ≤ 20. В отобранных выборках выделяют подлежащие верификации совокупности их фрагментов, содержащие n₁ элементов, где n₁ выбирают из условия 1,8 \leq (n₁+n)/n \leq 2. Осуществляют поиск во вспомогательном массиве данных смысловых единиц отличающихся погрешностью ОТ выделенных совокупностей фрагментов, выбираемой в пределах $\epsilon \le 0,1$ при $\alpha = 0,9 \, f_i =$ 0,01 - 0,1. Выявляют в распознанных смысловых единицах элементы, которые не совпадают с эквивалентными им по месту расположения символами в смысловых единицах, найденных в процессе поиска, и производят их замену соответствующими им по месту расположения символами из найденных смысловых единиц. Формируют дополнительный массив динамических растровых эталонов компьютерных кодов элементов В составе распознаваемых смысловых единиц количеством п7, величину которого по отношению к общему n₃ смысловых единиц в допустимом множестве смысловых единиц выбирают из условия $n_7/n_3 = 0.9$ при $\beta =$ 1,1, ϵ_1 = 0,05 и ϵ_2 = 0,05, пренебрегая в конкретном случае влиянием n_2 , n_5 , и n_6 на величину n₇. Преобразуют в результате вспомогательный массив данных уменьшения погрешности ϵ_3 по отношению к погрешности ε_1 из условия $(\varepsilon_1 + \varepsilon_3)/\varepsilon_1 = 1,2$.

N

တ

ത

Компьютерный код в заявленном объекте, как уже указывалось, - это преобразуемая компьютером совокупность электромагнитных соответствующих сигналов. адекватно распознаваемым исходным символам или любым другим распознаваемым фрагментам исходной информации. Каждый из эталонов динамических растровых СОВОКУПНОСТИ образующих эталонов, периодическую структуру, представляет собой, например, упорядоченный набор электромагнитных сигналов или соответствующих рельефно намагниченных фрагментов жесткого диска. Динамические свойства растровых эталонов определяют временными параметрами их преобразования.

отношении технических необходимых для реализации заявленного способа, целесообразно в дополнении к вышеизложенному отметить, что ими могут специализированные как блоки, функциональные узлы функциональные компьютера. управляемые задаваемой системой команд. В некоторые частности, операции осуществляются математическим сопроцессором центрального процессора блока системного компьютера управлением специализированных С операций массивами данных статистических вычислений функциональных программных блоков (библиотек команд, эталонов и других данных), производящих выборку и сортировку списков эталонов. Сами списки находятся либо в оперативной памяти (ОЗУ), либо на дисковом носителе компьютера и управляются системными библиотеками операционной команд среды. Под устройством человека заменяющим подразумевается любое устройство, которое может на необходимом для осуществления способа уровне выполнить операции, которые ранее выполнял или которые может выполнить человек. На практике техническими средствами реализации способа построения динамических растровых эталонов компьютерных кодов B процессе распознавания соответствующих им оригиналов могут являться, в частности, система состоящая из сканера, компьютера с загруженной оперативную память В программой сканирования, программой Fine Reader, подсистемой синхронизации компьютерных кодов, а также монитора, либо печатающего устройства и манипулятора для управления процессом. критерию промышленная Соответствие применимость предложенного способа также доказывается отсутствием в заявленных притязаниях каких-либо практически трудно

средств для их осуществления. Указанные в формуле изобретения отличия, как уже отмечалось, дают основание сделать вывод о новизне предложенного технического решения, а совокупность испрашиваемых притязаний - о неочевидности их создания или об их изобретательном доказывается уровне. что вышеприведенным способа. описанием использование Практическое обеспечивает достижение вышеуказанного технического результата взаимосвязанной совокупностью существенных признаков и особенностей, отраженных В формуле

реализуемых признаков и известностью

изобретения. Особенности использования способа и других объектов, не отраженные в описании, общеизвестны и не являются предметом изобретения.

Кроме указанного выше технического результата, практическое осуществление заявленного объекта позволяет существенно расширить возможности его использования применительно, например, к различным документам, заполняемым рукописными символами, либо документам плохого качества.

Формула изобретения:

Способ использования вспомогательных массивов данных в процессе преобразования и/или верификации компьютерных кодов, выполненных в виде символов, соответствующих ИМ фрагментов изображения, заключающийся в том, что производят выборку смысловых единиц распознаваемых фрагментов изображения, содержащих п составляющих их элементов, где n выбирают в пределах $1 \le n \le 10^3$, в отобранных выборках выделяют подлежащие верификации совокупности их фрагментов изображения, содержащие п 1 элементов, где n₁ выбирают в пределах 1 ≤(n₁ + n)/n ≤ 2, осуществляют поиск во вспомогательном массиве данных смысловых единиц, отличающихся от выделенных совокупностей фрагментов изображения, с погрешностью є, выдираемой в пределах $0 \le \varepsilon \le (\alpha n_1 - 1)/n_1$ где α - экспериментальный коэффициент в пределах $0.6 \le \alpha \le 1.2$, выбираемый в зависимости от части fi появления любой смысловой і-ой единицы в допустимом множестве смысловых единиц, которую определяют как количество

တ

повторений конкретной смысловой единицы, соотнесенное с общим количеством n₃ смысловых единиц в допустимом множестве смысловых единиц, выявляют в распознанных смысловых единицах элементы, которые не совпадают с эквивалентными им по месту расположения символами в смысловых единицах, найденных в процессе поиска, и производят их замену соответствующими им по месту расположения символами из найденных смысловых единиц, дополнительный формируют массив динамических растровых компьютерных кодов элементов в составе распознаваемых СМЫСЛОВЫХ количеством п₇, величину которого выбирают в пределах $1 \le (n_2 + n_5 + n_6 + \beta n_7 + n_3)/$ $n_3 \le 6,3$, где β - экспериментальный коэффициент в пределах $0.4 \le \beta \le 1.3$, выбираемый в зависимости от задаваемых погрешности ϵ_1 вспомогательного массива данных по отношению к допустимому множеству смысловых единиц, определяемой как вероятность ненахождения в массиве данных элемента пј, в общем количестве смысловых единиц п₄ во вспомогательном массиве данных. погрешности ε2 преобразования, определяемой как количество n 5 ошибочно преобразованных элементов, соотнесенное с общим количеством n₆ элементов преобразуемом наборе смысловых элементов из их допустимого множества, и преобразуют вспомогательный массив данных уменьшения погрешности ϵ_3 способа, которую

выбирают по отношению к погрешности ϵ_1 в

пределах $1 \le (\epsilon_1 + \epsilon_3)/\epsilon_1 \le 2$.

40

45

50

55

60